基于多源数据的马铃薯植株表型参数提取

胡松涛[1]，翟瑞芳[1*]，王应华[2]，刘　志[1]，朱剑忠[1]，
任　荷[1]，杨万能[2,3]，宋　鹏[2,3]

（1. 华中农业大学 信息学院，湖北武汉 430070；2. 华中农业大学 植物科学技术学院，湖北武汉 430070；3. 华中农业大学 作物遗传改良国家重点实验室，湖北武汉 430070）

摘　要：作物具有结构多样、生长环境复杂等特征。RGB图像数据能真实地反映植株的纹理特征与颜色特征，三维点云数据包含了作物的体量信息。将RGB图像和三维点云数据结合，实现作物的二维和三维表型参数提取，对表型组学的方法研究具有重要意义。本研究以马铃薯为研究对象，使用RGB相机和激光扫描仪分别采集了50个马铃薯的RGB图像与三维激光点云数据。对比了OCRNet，UpNet，PaNet和DeepLab v3+四种深度学习语义分割方法的分割精度，并选择精度较高的OCRNet网络实现马铃薯顶视图像的语义分割。优化了Mean shift聚类算法流程，完成了马铃薯植株激光点云的单株分割，并结合欧式聚类和K-Means聚类算法对单株马铃薯植株点云的茎和叶进行准确地分割。同时，提出一种利用编号建立马铃薯单株RGB图像和激光点云间一一对应关系的策略，并以此为基础分别从RGB图像与激光点云中提取同一马铃薯植株包括最大宽度、周长、面积、株高、体积、叶长与叶宽在内的8个二维表型参数与10个三维表型参数。最后，选择了比较具有代表性、易测量的叶片数、株高、最大宽度三个表型参数进行精度评估，平均绝对百分比误差（Mean Absolute Percentage Error，MAPE）分别为8.6%、8.3%和6.0%，均方根误差（Root Mean Square Error，RMSE）分别为1.371片、3.2 cm和1.86 cm，决定系数R^2分别为0.93、0.95和0.91。精度评估的结果表明，所提取的表型参数能够准确、高效地反映马铃薯的生长状态，将马铃薯的RGB影像数据与三维激光点云数据相结合，能够充分发挥RGB图像纹理颜色特征丰富、三维点云能够提供体量信息的优势，实现马铃薯植株二维与三维表型参数高精度、非破坏性的提取。本研究成果不仅可以为马铃薯的种植和育种提供重要的技术支持，还可以为基于表型数据的研究提供有力支持。

关键词：LiDAR；多源数据；聚类分割；三维表型；OCRNet；激光点云；深度学习

中图分类号：S330；S532　　　**文献标志码：**A　　　**文章编号：**SA202302009

引用格式：胡松涛，翟瑞芳，王应华，刘志，朱剑忠，任荷，杨万能，宋鹏. 基于多源数据的马铃薯植株表型参数提取[J]. 智慧农业(中英文)，2023，5(1)：132-145.

HU Songtao, ZHAI Ruifang, WANG Yinghua, LIU Zhi, ZHU Jianzhong, REN He, YANG Wanneng, SONG Peng. Extraction of potato plant phenotypic parameters based on multi-source data[J]. Smart Agriculture, 2023, 5(1): 132-145.

1　引　言

作物表型被用于定量评估植物的各项性状，对现代农业种植具有重要的意义[1]。早期作物表型的获取通过人工完成，如用卷尺测量株高、使用排水法测量体积等，不仅效率低，而且涉及破坏性测量，难以实现作物发育的持续性监测。因此，探索一套高效的、非破坏性的、可利用不同数据源的方法来获取植物的表型参数，成为作物表型领域的研究热点。

其中，基于RGB图像与激光点云的方法得到了广泛应用。在高通量作物表型参数获取中，RGB

收稿日期：2023-02-28

基金项目：国家自然科学基金（U21A20205）

作者简介：胡松涛，硕士研究生，研究方向为机器视觉与图像处理。E-mail：cxvd3ttak@163.com

*通信作者：翟瑞芳，博士，副教授，研究方向为LiDAR数据处理。E-mail：rfzhai@mail.hzau.edu.cn

图像能够反映植株的形态，而且包含了丰富的颜色特征、纹理特征等，是获取表型参数的首选数据。Germain等[2]通过区分图像中灰度值的差异，从二维图像中提取到麦穗，并获得了不错的结果。王传宇等[3]使用局域纹理能量滤波器获得玉米叶片的边缘轮廓，成功从图像中分割出玉米叶片；Loresco等[4]在RGB、CIELab、YCbCr和HSV四个不同颜色空间，使用K-邻近算法分割生菜图像，发现CIELab颜色空间具有最好的分割性能，并将其应用于智能农场作物阶段识别。

近年来，深度学习成为了图像处理的热门方法。它克服了传统图像处理方法需要人为设计并手工提取特征的缺点，并且训练出的模型具有更高的准确性与普适性。Grinblat等[5]使用卷积神经网络（Convolutional Neural Networks，CNN）对白豆、大豆、红豆三种豆科植物的叶片进行识别与分类，整体的准确率达到96.9%。Lee等[6]同样使用CNN成功训练出用于有效区分44种植物叶片的模型，准确率最高可达99.5%。近年来，解决像素级分割问题和解决目标检测问题的各种优秀的网络模型不断涌现，并且在植物表型领域得到了广泛使用。Fan等[7]将YOLOv4模型部署在田间表型机器人上，使用其测量玉米主茎的直径；王晓婷等[8]采用迁移学习与Mask R-CNN模型实现对西瓜植株的检测与分割。

点云数据由于具有几何特征丰富、受外界环境影响较小等优势，近年来也受到了表型研究人员的关注。点云的采集方式分为两种：一种是基于主动的三维测量方法，如激光点云，具有高密度、高精度的特点，点云中点的信息直接来源于传感器，包含大量的语义信息[9]；第二种是基于被动的三维测量技术，主要通过序列影像重建的算法生成点云，被称为重建点云[10]。激光点云相比重建点云具有获取效率高、精度高以及点云中点的分布更加均匀等优势[11]。点云的处理算法是获取作物表型参数的关键。常规点云数据处理主要包括滤波、配准、特征提取、识别与分割。对于作物表现参数的提取而言，分割尤为重要。已有不少研究人员针对某一个或一类植物使用激光扫描技术提取表型参数。Wang等[12]使用Kinect v2.0设备对植物点云进行提取，并使用基于凹凸性的聚类分割算法完成植物的叶片分割，实现对叶片性状的测量；阳旭等[13]使用手持激光扫描仪获取3株棉花共12个时间点的点云数据，实现对叶片与主茎的分割，并对株高、叶长、叶宽、体积等表型参数的动态测量。这些方法需要的数据量小，算法结构简单，应用广泛。

马铃薯是一种兼用型农作物，水分利用率高、产业链长、种植面积大，对缓解食物安全压力起到重要作用[14]。近年来，马铃薯的表型参数提取逐渐受到国内研究人员的关注。针对RGB图像，张兆国等[15]改进了YOLOv4模型，实现了对复杂环境下的马铃薯块茎的识别与计数；赵越等[16]使用Fater R-CNN网络对马铃薯叶片实现病害检测。针对激光点云，谭彧等[17]使用深度相机采集马铃薯块茎点云并从中获取了马铃薯芽眼的三维定位。

为结合RGB图像和激光点云二者的优点，本研究使用RGB相机与激光扫描仪采集马铃薯的RGB图像与点云数据，获取单株作物的18项表型参数，精度评估结果表明，将RGB图像和激光点云相结合的方法，能够同时获取同一马铃薯植株的纹理和形态特征，并且弥补了单一数据形式的局限性。

2　材料与方法

2.1　技术路线

本研究使用RGB相机与激光扫描仪分别采集马铃薯的RGB图像与点云数据，通过编号建立马铃薯图像与点云之间的对应关系，并在此基础上提取单株马铃薯的二维与三维表型参数，整体技术流程如图1所示。

2.2　RGB图像与点云数据采集

马铃薯植株于2022年4月在表型平台温室中分盆种植，共800盆，每盆种植1株，待生长情况稳定后开始数据的采集工作。本研究共对50株马铃薯进行RGB图像与点云数据的采集，用于之后的表型参数提取。另外，本研究还分别在5月15日、5月18日、5月21日、5月24日和5月27日从另外750株马铃薯中采集了4000幅RGB图像数据，用于

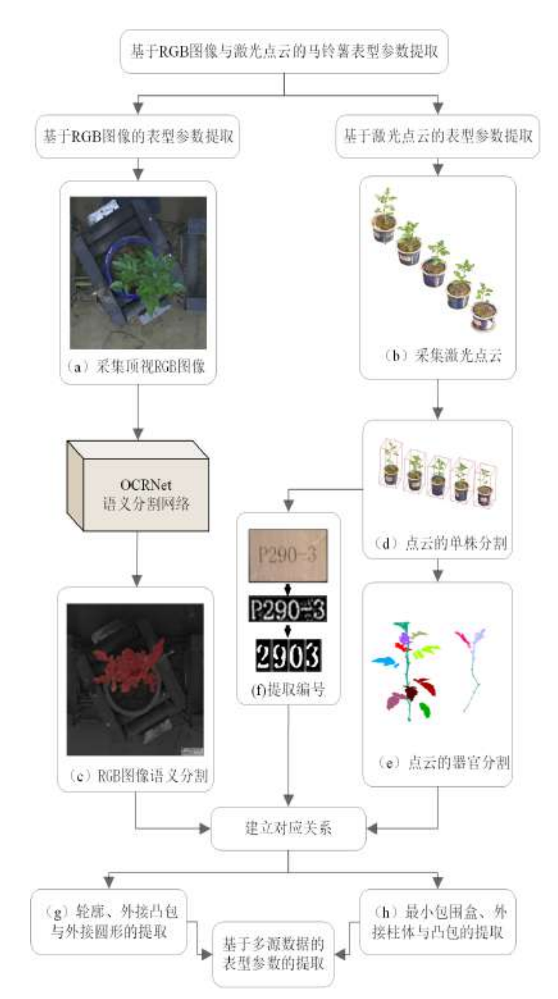


图1　基于RGB图像与激光扫描仪提取马铃薯表型参数的技术路线

Fig. 1 Technical route of extracting potato plant phenotypic parameters based on RGB image and point clouds

深度学习语义分割网络的训练。

本研究使用的RGB相机为德国巴斯勒公司生产的Basler aca5472，有效像素为2000 w/in。使用的激光扫描仪为美国FARO公司研发的Focus S70，其分辨率最大为976,000点/s。激光扫描仪在扫描过程中使用的辅助扫描工具为激光扫描标记球与支架。RGB相机与激光扫描仪的数据输入、存储与处理使用一台运行内存32 GB，处理器主频为2.8 GHz的Windows 64位操作系统惠普笔记本电脑，图2分别为本研究中数据采集设备与使用的马铃薯植株。

2.2.1　RGB图像的采集

马铃薯的生长发育与其冠层密切相关。冠层是马铃薯植株进行光合作用和呼吸作用的主要部分，



(a)RGB图像采集传送带与暗室



(b)暗室顶部的RGB相机



(c)激光扫描仪与扫描现场



(d)激光扫描仪的站点布置

图2　马铃薯激光点云数据采集试验设备与现场布置

Fig. 2 Equipment and site layout of LiDAR points cloud data acquisition of potato

为植株积累大量的有机物。因此，马铃薯的冠层最能直接反映植物的各方面状态。使用RGB相机从正上方获取马铃薯植株的顶视图像，能最大程度地获取马铃薯植株冠层特征。

本研究使用一套位于华中农业大学作物表型平台中的自动传输装置[18]在密闭暗室的环境中对马铃薯植株进行周期性的图像采集工作，如图2（a）所示。采集顶视图像的RGB相机悬挂于密闭暗室的顶部，如图2（b）所示。自动传输装置由三条滚筒输送线组成，分别负责将植株送入暗室、调整植株位置以便获取顶视图像、将植株送出暗室的工作。RGB相机距离输送线的高度为1.5 m，该高度可以保证图像的尺寸正好覆盖整个暗室，避免了图像中出现数据缺失的问题。

2.2.2　激光点云数据采集

马铃薯的激光点云数据采集以10株马铃薯为一组，共设置9个站点，马铃薯依次从低到高排列，如图2（c）所示。为了减少主茎点云与靠近根部的叶片点云缺损，5个站点（如图2（d）中蓝色方块所示）中的激光发射器与被扫描马铃薯平行，另外4个站点（如图2（d）中绿色方块所示）则稍高于被扫描马铃薯。

激光扫描结果受设备参数设置的影响较大，需要通过实验确定最优参数设置方案，包括分辨率与质量。分辨率是激光雷达扫描得到点云的密度，质量是激光雷达发射激光束的数量。实验使用6盆马铃薯作为对象，设置6个对照组，每个对照组设置不同的分辨率与质量，在同一天先后完成扫描。本研究将根据实验结果设置激光扫描仪的参数，并对马铃薯植株进行激光点云数据的采集。

2.3 图像的语义分割

OCRNet网络[19]是一种基于全卷积神经网络的语义分割网络，结构如图3所示。OCRNet网络利用物体上下文特征表达方法，将冗杂的像素分类问题转化为更高层次的分类问题，提高了像素分类的准确性。OCRNet网络主要包括三个步骤：第一步，使用主干网络进行语义分割，并从中获取像素特征和类别特征；第二步，将类别特征和像素特征展开成二维向量，并进行融合；第三步，通过自注意力机制计算相关性向量，然后将相关性向量与像素特征进行拼接，从而获得基于物体类别的上下文信息。OCRNet网络能够将上下文信息集中于物体本身，降低干扰，提高像素的分类准确性。采用OCRNet网络能够有效地提高边缘的识别和分割效果，尤其适用于结构复杂、语义信息丰富的马铃薯RGB图像。

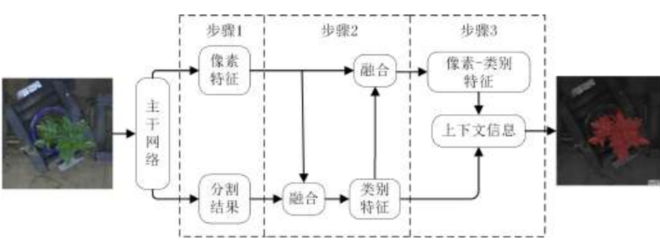


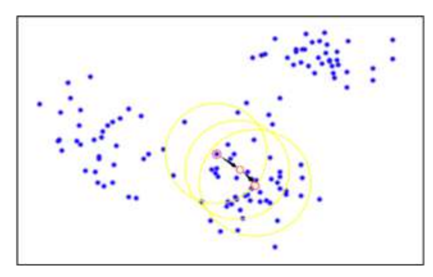
图3 研究中使用的OCRNet的网络结构

Fig. 3 The OCRNet network architecture used in the study

2.4 点云的分割

2.4.1 点云的单株分割

激光扫描仪采集到马铃薯点云数据后，需要将所有点云数据分为独立的单株马铃薯点云。均值漂移（Mean Shift）算法[20]对数据的密度较为敏感，因此本研究采用均值漂移算法来实现单株马铃薯点云的分割。均值漂移算法的基本流程如图4所示：先从点集中的任意一个点p出发，遍历以点p为球心、r为半径的球体内所有的点，并求出这些点到点p的向量的平均值，得到均值漂移向量，之后将均值漂移向量的终点作为新的点p，如果p不再移动，则选择下一个点进行均值漂移，直到所有的点都完成移动。



注：图中红色圆圈为点p，黄色圆圈是以点p为圆心，半径为r的搜索邻域，黑色箭头为漂移向量

图4 均值漂移算法的步骤

Fig. 4 The steps of the mean shift algorithm

激光扫描仪在扫描过程中会出现遮挡，使得部分植株的中间区域点云相对稀疏。若直接利用均值漂移算法对点云进行聚类，同一植株的点云容易被误分为上下两层。为了解决此问题，本研究优化了均值漂移算法聚类的流程，首先将待分割点云投影至与水平地面平行的XoY平面，构成一个二维离散点集，再使用均值漂移算法对该点集进行聚类，待聚类完成后，将二维离散点集还原为三维点云，即可避免出现点云被误分为上下两层的问题。同时，优化后的均值漂移算法聚类中，点漂移208,557次、用时24,2684 ms，相比优化前减少45,432次、节省了195,180 ms，大大提高了马铃薯的点云单株分割效率。

2.4.2 作物点云的器官分割

马铃薯叶片的表型参数为评估植物性状提供了重要的参考依据。对马铃薯点云的叶片与主茎进行分割，可以精确地从叶片中提取表型参数，而且不对植株本身造成破坏。马铃薯植株中，生长点下部的叶片分布均匀、主茎与叶片间距较大、各个叶片与主茎在密度上差异较小；生长点附近的叶片较为密集、点云中叶片与主茎间距较小、噪声与重影较为明显。基于马铃薯植株的上述特点，本研究将分两步对马铃薯点云进行器官分割，如图5所示。第一步，使用对距离敏感的欧式聚类算法（Euclidean Cluster Extraction Algorithm）[21]，提取马铃薯植株

点云中生长点下部的叶片，并将未分割的生长点附近叶片与主茎送至下一步；第二步，基于第一步分割的结果，使用能够深入各挖掘点之间相似特点的K-Means聚类算法[22]，对上一步未完成分割的生长点附近叶片与主茎进行分割。经过两个步骤，所有叶片（包括生长点下部叶片与生长点附近叶片）都成功与主茎分离，流程结束。

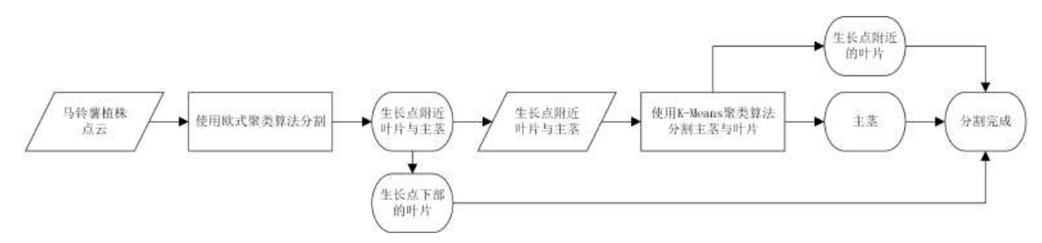


图5 马铃薯植株点云器官分割的流程

Fig. 5 The point cloud organ segmentation process of potato plant

2.5 单株马铃薯RGB图像与激光点云数据的对应

激光扫描仪和RGB相机的采集时间不一。而且，为了确保每幅RGB图像中马铃薯的比例相同，需要固定RGB相机和马铃薯植株的相对位置。而激光扫描仪在采集马铃薯点云的过程中需要多次调整位置和高度。因此，采用同步采集方式会限制其灵活性并影响马铃薯植株点云的质量。因此，本研究采用异步方式采集马铃薯植株的RGB图像和激光点云，以提高数据采集效率并增强灵活性。

为了建立异步采集获得的马铃薯RGB图像和激光点云数据之间的一一对应关系，从而提取同一株马铃薯的表型参数，本研究提出了一种新的策略，利用每盆植株的编号完成对应关系的建立。对于RGB图像，本研究使用了自动传输装置，按照编号从小到大采集图像，输出的RGB图像可以自然实现图像与马铃薯植株编号的一一对应。对于激光点云数据，需要从单株马铃薯的激光点云数据中提取编号，完成点云数据与马铃薯植株编号的一一对应。针对单株马铃薯点云，提取编号的步骤如下：

（1）使用颜色阈值对点云数据进行粗过滤，如图6（b）所示。点云的颜色特征通过求取红、蓝、绿三个颜色分量的平均值获得。标签的颜色特征在（140,180）的范围内；

（2）使用聚类算法定位编号标签在点云数据中的位置，如图6（c）所示；

（3）求取编号标签点云中点的平均法向量，如图6（d）所示；

（4）将编号标签点云沿平均法向量方向投影至与平均法向量垂直的平面，如图6（e）所示；

（5）对编号标签的二维投影图像进行图像处理，获取数字编号，如图6（f）与6（g）所示。

在二值化的过程中，传统的二值化方法基于固定阈值划分像素，无法处理光照不均的情况，如图7（b）所示。因此，本研究采用了能够对图像进行局部二值化的Sauvola算法[23]处理编号标签投影图像。Sauvola算法根据像素点邻域内的灰度值和标准差动态计算阈值，有效抑制了光影变化对数字提取的影响，如图7（c）所示。Sauvola算法计算动态阈值公式（1）～（3）所示。

$$m(x,y)=\frac{1}{r^2}\sum_{i=x-\frac{r}{2}}^{x+\frac{r}{2}}\sum_{j=y-\frac{r}{2}}^{y+\frac{r}{2}}\mathrm{gary}(i,j) \tag{1}$$

$$s(x,y)=\sqrt{\frac{1}{r^2}\sum_{i=x-\frac{r}{2}}^{x+\frac{r}{2}}\sum_{j=y-\frac{r}{2}}^{y+\frac{r}{2}}\left(g(i,j)-m(i,j)\right)^2} \tag{2}$$

$$T(x,y)=m(x,y)\times[1+0.1\times(\frac{s(x,y)}{R}-1)] \tag{3}$$

其中，r表示以当前像素点（x，y）为中心的邻域范围；R是动态范围，由标准差计算而来，当图像灰度为8位时，R的值始终为128。在像素点（x，y）的$r\times r$邻域内，灰度值的平均值表示为m（x，y），标准方差表示为s（x，y），像素点（x，y）的动态阈值表示为T（x，y）。

在二维投影图像的获取过程中，数字的轮廓会发生变形。因此，本研究选用了经典的MNIST手

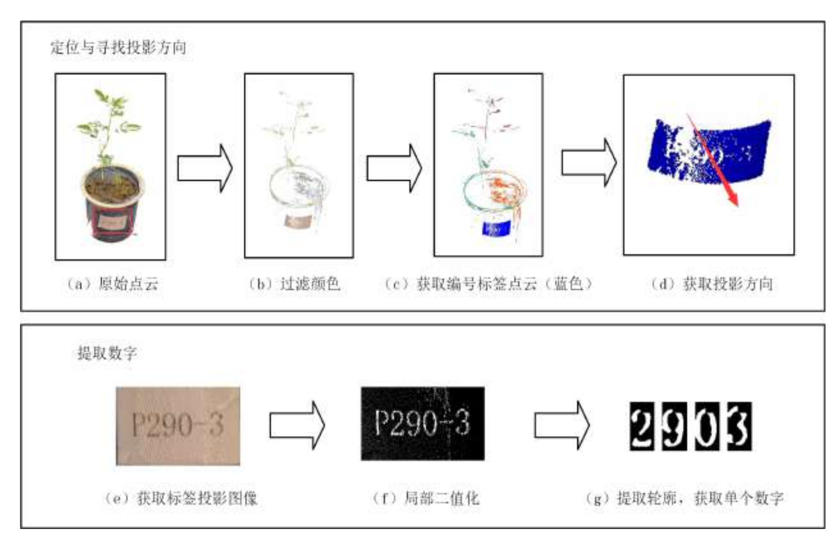


图6 利用编号建立马铃薯单株RGB图像和激光点云间一一对应关系方法中从点云中提取数字的过程

Fig. 6 The process of extracting numbers from point clouds in the method of establishing one-to-one correspondence between potato single-plant RGB images and laser point clouds using identifiers

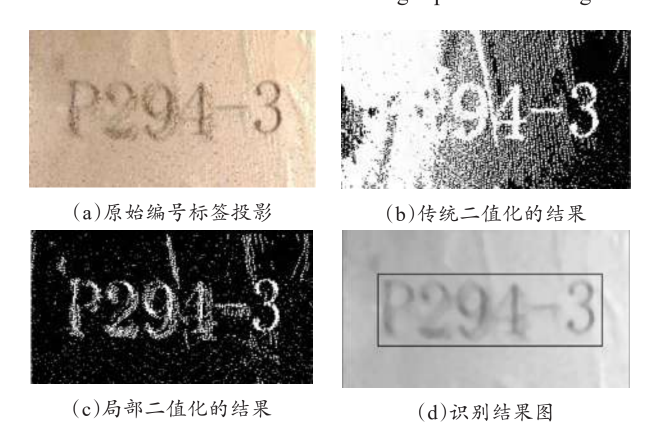


图7 编号标签投影图像二值化的结果对比

Fig. 7 Comparison of the results of binary projection of numbered labels in images

写数字数据集[24]，使用了深度卷积神经网络AlexNet[25]对数字进行自动识别。AlexNet网络包括5个卷积层、3个池化层和3个全连接层，使用ReLU作为激活函数。此外，AlexNet还应用了Dropout正则化和局部响应归一化技术，以减少过拟合的风险并增强网络的泛化能力和鲁棒性。

2.6 马铃薯植株表型参数的提取

马铃薯的主茎和冠层是作物在生长过程中的最活跃的部位，叶片是作物进行光合作用和呼吸作用的主要载体。冠层、主茎、叶片的特征变化都为评估植物性状提供了重要的参考依据，获取这些信息对后续的分析与育种具有重要意义。本研究从同一植株的RGB图像与激光点云中，共提取出与冠层、主茎、叶片等有关的18个表型参数。各参数的名词、缩写与特征类型如下：

二维形态特征：最大宽度（CW）、周长（CP）、面积（CA）、凸包周长（CHC）、凸包面积（CHA）；

二维纹理特征：均值（MI）、平滑度（SE）、标准差（S）；

三维形态特征：株高（PH）、横向宽度（PW）、纵向宽度（PD）、凸包体积（PV）、柱体体积（CV）、叶片数（LN）、叶片长度（LL）、叶片宽度（LW）、叶片面积（LA）、投影面积（PA）。图8为马铃薯植株表型参数的提取。

2.6.1 二维形态特征

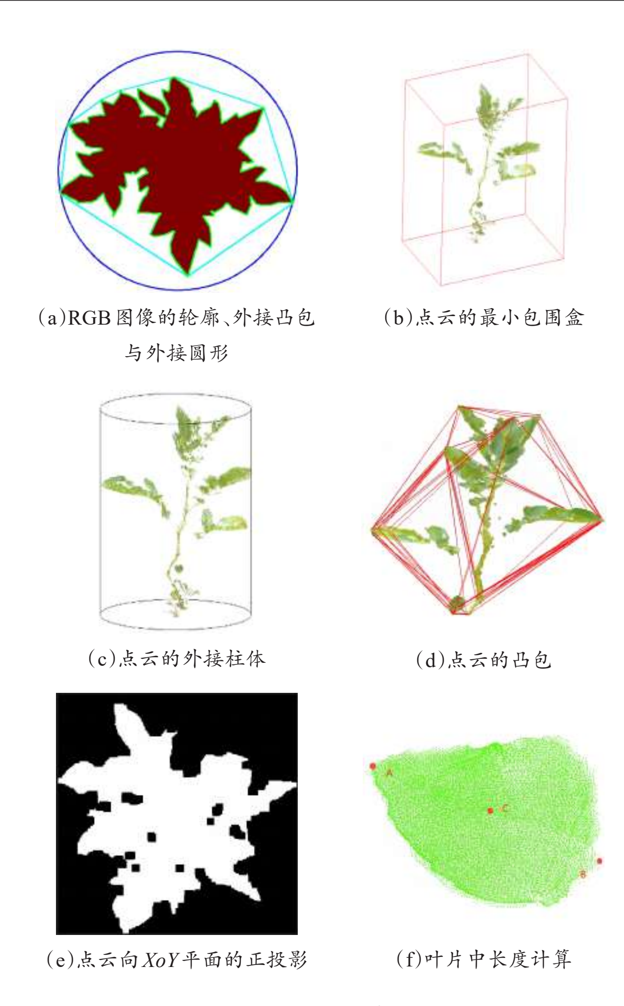
轮廓：如图8（a）绿色线所示。统计边缘线像素点个数即可得到周长，统计轮廓中红色区域像素点个数即可得到面积。

外接凸包：如图8（a）浅蓝色线所示。可以提取凸包周长与凸包面积。

外接圆形：如图8（a）深蓝色线所示。外接圆形的半径可以作为最大宽度。

2.6.2 二维纹理特征

马铃薯图像的纹理特征是反映图像特性的重要特征。图像纹理特征可以反映图像的粗糙度、方向性、有序程度。图像的粗糙度为图像中最小的结构



(a)RGB图像的轮廓、外接凸包与外接圆形　(b)点云的最小包围盒

(c)点云的外接柱体　(d)点云的凸包

(e)点云向XoY平面的正投影　(f)叶片中长度计算

图 8　马铃薯植株表型参数的提取

Fig. 8 Extraction of potato phenotypic parameters

单元的大小，一般情况下，图像中最小的结构单元越小，图像越细腻。方向性为像素的灰度与相邻区域的梯度的一致性。有序程度表示最小单元结构排布规律的有序性[26,27]。本研究主要提取了能够反映图像粗糙度、方向性、有序性的三个重要纹理特征，分别为均值、标准差和平滑度。这个三个纹理特征使用灰度直方图计算，具体分别如公式（4）～（6）所示。

$$M = \sum_{i=0}^{L-1} z_i P(z_i) \tag{4}$$

$$\sigma^2(z) = \sum_{i=0}^{L-1} (z_i - M)^2 P(z_i) \tag{5}$$

$$R(z) = 1 - \frac{1}{1 + \sigma^2(z)} \tag{6}$$

其中，灰度级范围从0到L−1；z_i代表图像中点的灰度值；P（z_i）代表灰度直方图中灰度z_i的出现频率；M代表灰度的均值；σ（z）代表灰度的标准差；R（z）代表图像的平滑度。

2.6.3　三维形态特征

激光点云可以准确地反映马铃薯在三维空间中完整的形态特征。从本研究得到的点云与器官分割结果中可以提取到10个表型参数。其中6个表型参数从单株点云中直接获得，4个表型参数从器官分割后的结果中获得。

最小包围盒与外接柱体：如图8（b）与图8（c）所示，激光扫描仪采集的点云，Z轴始终与地面垂直，因此最小包围盒与外接柱体的高度可以作为株高，最小外接包围盒的宽度或外接柱体的长轴可以作为横向宽度，最小外接包围盒的深度或外接柱体的短轴可以作为纵向宽度。外接柱体的体积可以表示三维空间中作物植株占据的空间大小。

凸包：如图8（d）所示，凸包是三维空间中能够包含一组点的最小凸多面体，因此通常用于表示三维空间中作物植物本身的体积，如图8（d）所示。

投影：如图8（c）所示，特指植株点云向XY平面的正投影与处理后获得的图像。通过统计白色区域的像素个数计算投影面积，如图8（e）所示。

从器官分割后的结果中获取的表型参数为马铃薯叶片的叶长与叶宽。马铃薯的叶片在生长到一定程度后会出现明显弯曲。因此，直接使用叶片两端的欧式距离值来测量叶长和叶宽会造成较大的误差。在本研究中，叶长与叶宽使用逼近方法测量。如图8（f）所示，人工选取点云上的端点A和B，AB两个端点之间的距离为L。人工选取AB的中间点C，并分别计算点A、C和点B、C之间的距离D_l和D_2。设l为D_l与D_2之和。在L和l之间的长度偏差上设置阈值d，并比较L和l，如公式（7）所示：

$$l = \begin{cases} L + d, & \sqrt[2]{(L-l)^2} < d \\ D_1, & \sqrt[2]{(L-l)^2} \geq d \end{cases} \tag{7}$$

如果L和l之间的长度偏差上大于或等于阈值d，则用区段D_l更新l，并用B替换区段D_l中的端点标签C，直到L和l之间的长度偏差上小于阈值d。

2.6.4　精度评估指标

为了验证本研究提出方法的有效性，本研究在数据采集阶段收集了植物叶片数的人工计数数据与株高、最大宽度的人工测量数据。通过计算从RGB

图像与点云中提取的表型参数与点云中提取的表型参数同人工计数、测量结果之间的相对误差，评估从作物RGB图像与点云数据中提取表型的准确性。

精度评估分别通过平均绝对百分比误差（Mean Absolute Percentage Error，MAPE）、均方根误差（Root Mean Square Error，RMSE）和决定系数（Coefficient of Determination，R^2）来实现。

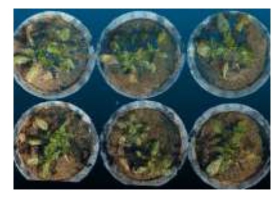
3 试验结果与分析

3.1 激光扫描仪参数设置

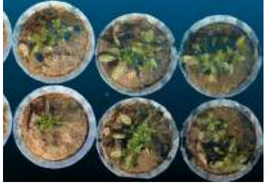
为了选择合适的激光扫描参数，本研究设计了一组对照实验，使用6盆马铃薯作为对象，设置6个对照组，每个对照组设置不同的分辨率与质量，在同一天先后完成扫描。实验中每组的参数与扫描结果如图9所示。第一组虽然效果较好，但存在点云数据冗余、配准精度不高、耗时过长等问题；第四组、第五组和第六组的结果可以看出，点云数据分辨率低于1/4×976,000点/s，无法获得较好的结果；通过第二组与第三组的对比可以看出，第三组的点云密度更高，所携带的形态特征也就更多、更准确。综合点云数据的视觉效果、配准的精度与时间效率三个角度考虑，激光雷达在分辨率为1/4×976,000点/s、质量为4X的情况下能够获得良好的效果，且能够保证较高的效率。



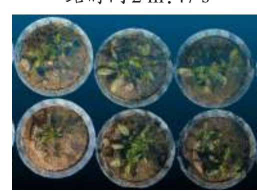
（a）第一组，分辨率为1/2×976,000点/S，质量为2X，单站时间8 m：09 s



（b）第二组，分辨率为1/4×976,000点/s，质量为2X，单站时间2 m：47 s



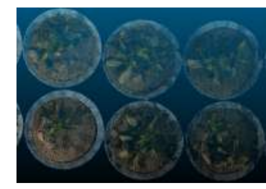
（c）第三组，分辨率为1/4×976,000点/S，质量为4X，单站时间8 m：09 s



（d）第四组，分辨率为1/5×976,000点/s，质量为4X，单站时间5 m：35 s



（e）第五组，分辨率为1/8×976,000点/s，质量为4X，单站时间2 m：47 s



（f）第六组，分辨率为1/8×976,000点/s，质量为6X，单站时间8 m：09 s

图9 FARO Focus S70激光扫描仪分辨率与质量选择实验结果

Fig. 9 Results of resolution and quality selection experiment of FARO Focus S70 laser scanner

3.2 RGB图像语义分割

本研究首先使用Python脚本将1600张马铃薯植株顶视RGB图像切分为800×800像素大小，并使用Labelme工具进行标注。其中，1200张马铃薯植株顶视RGB图像按照7：3的比例划分为训练集和验证集，剩下的400张用作测试集。

使用OCRNet、DeepLab v3+[28]、UPerNet[29]和PANet[30]四种不同的深度学习语义分割网络对马铃薯植株顶视RGB图像进行分割，并比较它们的三个精度评估指标：目标像素精度（Pixel Accuracy，PA）、平均像素精度（Mean Average Precision，MPA）和平均交并比（Mean Intersection over Union，MIoU），对比结果如表1所示。结果表明，这四个模型的MPA和MIoU评分都十分接近，而OCRNet在平均像素精度和目标像素精度两个方面表现最优，仅在平均交并比方面略逊于DeepLab v3+网络。

表1 四种深度学习语义分割网络分割马铃薯植株的性能比较

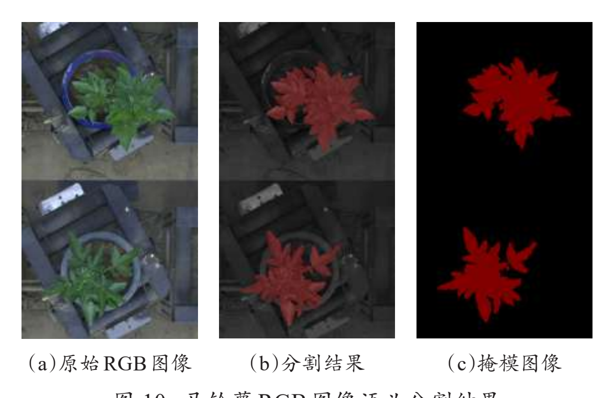
Table 1 Performance comparison of four deep learning semantic segmentation networks for segmenting potato plants

网络名称	PA/%	MPA/%	MIoU/%
UPerNet	97.56	98.65	97.38
OCRNet	98.22	98.95	97.48
PANet	98.01	98.83	97.18
DeepLab v3+	98.06	98.54	97.67

OCRNet网络通过将上下文信息聚焦于物体本身，降低上下文信息对像素类别的干扰，从而为像素分类提供有益信息。OCRNet网络的优点在于它可以使上下文信息更专注于物体，并将物体的信息传递到每个像素上，从而降低了噪声和干扰，提高

了像素的分类准确性。在处理复杂的马铃薯植株形态和丰富的像素上下文信息方面，采用OCRNet网络能够获得较好的分割结果。

综上所述，本研究主要采用OCRNet网络进行马铃薯植株的语义分割，并将该结构用于后续的表型参数提取和精度分析。部分RGB图像分割结果如图10所示。



(a)原始RGB图像　(b)分割结果　(c)掩模图像

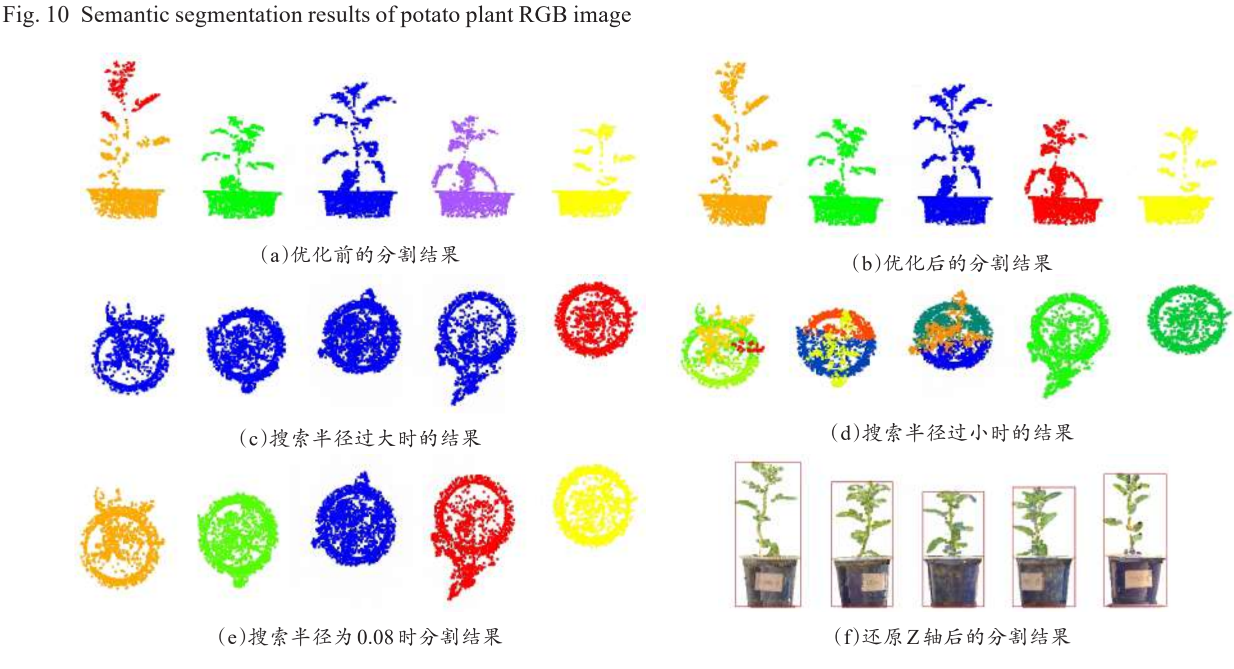
图 10　马铃薯RGB图像语义分割结果

Fig. 10 Semantic segmentation results of potato plant RGB image

3.3 植株点云的分割

3.3.1　植株点云的单株分割

本研究使用优化流程后的均值漂移算法完成作物点云的单株分割任务。对比图11（a）与11（b）可以看出，优化流程后的均值漂移算法能够有效避免误分割问题。均值漂移算法需要设置停止迭代的阈值和搜索半径。停止迭代的阈值用于判断漂移是否已经收敛，一般设置为0.00001。搜索半径决定了每个样本点的邻域范围，过大的搜索半径会将不同的簇误认为是同一个簇，导致聚类结果模糊，如图11（c）所示。过小的搜索半径会使得局部密度估计的范围太小，同一个簇中的数据点被划分到不同的簇中，导致聚类结果错误，如图11（d）所示。经过一系列搜索半径参数验证实验，搜索半径为0.08时，可以取得较好的分割结果，如图11（e）与11（f）所示。



(a)优化前的分割结果　(b)优化后的分割结果

(c)搜索半径过大时的结果　(d)搜索半径过小时的结果

(e)搜索半径为0.08时分割结果　(f)还原Z轴后的分割结果

图 11　马铃薯植株点云单株分割的结果

Fig. 11 Results of single-plant segmentation of potato plant point cloud

3.3.2　植株点云的器官分割

为了能够准确地分割叶片与主茎，作物点云的器官分割分两步进行。第一步中，欧式聚类算法需要设置近邻搜索半径、最小聚类点数和最大聚类点数三个参数。最小聚类点数和最大聚类点数用于排除噪声，根据叶子的点云分布情况，一般最大聚类点设置大于点云数量的一半、最小聚类点设置不超过点云数量的10%；近邻搜索半径和点云的平均密度、均匀程度有关，如果近邻搜索半径小于最优值会出现大量误分割结果，如图12（b）所示；如果近邻搜索半径大于最优值，则点云无法分割，如图12（c）所示。经过一系列试验的验证，在最小聚类点数为1000、最大聚类点数为200,000、近邻搜索半径为5 mm时，可以取得较好的分割结果，

如图12（a）所示，马铃薯植株的生长点下部叶片的分割基本完成，仅生长点附近的叶片仍与主茎相连。生长点附近的叶片与主茎的分割通过第二步完成。

第二步中使用K-Means聚类算法对生长点附近叶片与主茎进行分割。当叶片数量较少、叶片与主茎的密度特征明显时，使用一次K-Means聚类算法即可完成分割，K值设置为生长点附近叶片的数量加1，如图12（d）所示；当叶片数量较多、叶片与主茎的密度特征不明显时，需要使用多次K-Means聚类算法对茎叶相连的部分进行分割，每一次分割，K值设置为生长点附近剩余叶片的数量加1。本研究中，分割生长点附近叶片与主茎最多使用两次K-Means聚类算法。第二步中需要使用两次K-Means聚类算法的分割结果如图12（e）与图12（f）所示。



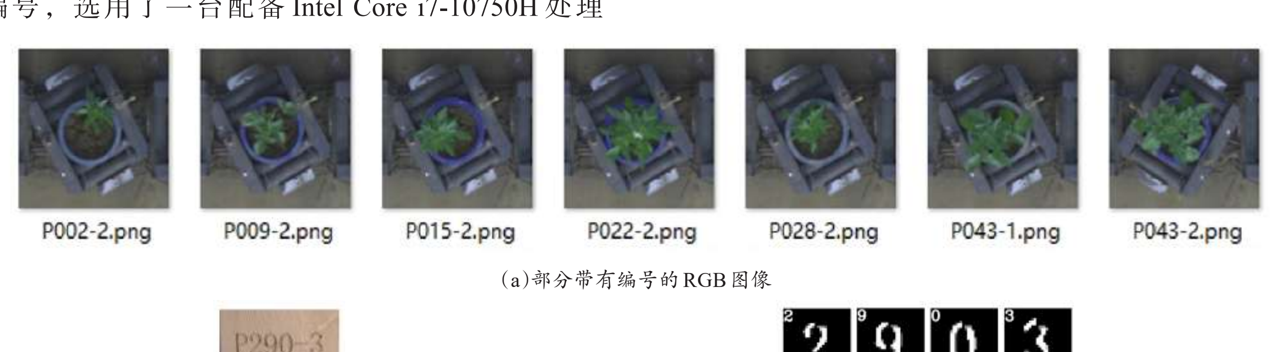
(a)近邻搜索半径为最优值时分割结果　(b)近邻搜索半径小于最优值时分割结果　(c)近邻搜索半径大于最优值时分割结果　(d)仅使用一次K-Means聚类算法分割结果　(e)使用两次K-Means聚类算法，第一次分割结果　(f)使用两次K-Means聚类算法，第二次分割结果

图12　马铃薯植株点云器官分割的结果

Fig. 12 Organ segmentation results of potato plant point cloud

3.4 植株RGB图像与激光点云间的对应

本研究利用每盆马铃薯植株盆体上的编号，通过自动传输装置按编号从小到大采集图像，成功地实现了RGB图像与马铃薯植株编号的一一对应，如图13（a）所示。为了从马铃薯点云中提取相应编号，选用了一台配备Intel Core i7-10750H处理器、16 G内存和NVIDIA GeForce RTX 2060显卡的Windows工作站，并以Pycharm作为开发环境，使用Python 3.7语言实现了编号标签点云投影获取的算法。在Pytorch1.7.1和CUDA版本11.1的软件环境下，应用AlexNet网络成功地实现了对编号的识别，结果如图13（b）与13（c）所示。



(a)部分带有编号的RGB图像

(b)原编号标签点云投影图　(c)数字识别结果

图13　马铃薯植株RGB图像与激光点云间对应关系建立的结果

Fig. 13 Results of establishing correspondence between potato plant RGB image and laser point cloud

3.5 精度评估结果

为了进一步验证本研究所使用的方法具有实用价值，需要对提取的参数进行精度评估。然而，人工测量植株体积会导致植株受损，而叶片相关参数、周长和面积的人工测量方法繁琐，且受到主观因素的影响。此外，图像的纹理特征和投影面积还没有可靠的人工测量方法。因此，本研究选取最大宽度、株高和叶片数三个代表性表型参数进行精度评估。其中，最大宽度的精度评估结果证明了RGB图像可以精准地提取表型参数；株高的精度评估结果证明了使用激光点云从马铃薯中提取表型参数的方法的可行性；对叶片数进行的精度评估则说明了叶片分割流程的可靠性。这三种表型参数的精度评估结果证明了参数提取方案的可行性，进而间接证明了相关参数的精确性。叶片数、株高与最大宽度的算法测量值与人工测量值如表2所示。

表 2 马铃薯计算叶片数、株高、最大宽度与人工测量值的比较

Table 2 Results comparison of leaf number, plant height, and maximum width of potatoes with artificial measurements

编号	叶片数/片		株高/m		最大宽度/m	
	算法测量值	人工计数值	算法测量值	人工测量值	算法测量值	人工测量值
5-12-P104-2	4	7	0.2681	0.3000	0.1390	0.1387
5-12-P104-2(2)	5	6	0.2369	0.2830	0.1880	0.1803
5-12-P104-3	8	9	0.3281	0.3180	0.1740	0.1986
5-12-P279-3	16	16	0.2645	0.3060	0.2370	0.2761
5-12-P281-1	10	10	0.2446	0.2530	0.1630	0.1671
5-12-P281-2	10	12	0.2708	0.3010	0.2490	0.2455
5-12-P281-3	13	13	0.3076	0.3190	0.2490	0.2436
5-12-P294-3	12	12	0.2814	0.2860	0.2190	0.2430
5-12-P297-1	8	8	0.2744	0.2570	0.2420	0.2744
5-12-P002-2	10	11	0.1871	0.2140	0.2340	0.2342
5-12-P009-2	8	8	0.2661	0.2890	0.1430	0.1504
5-12-P015-2	12	12	0.2763	0.3140	0.1420	0.1465
5-12-P022-2	14	12	0.3677	0.3620	0.1790	0.1867
5-12-P028-2	8	9	0.2026	0.2480	0.2290	0.2135
5-12-P043-1	10	12	0.3409	0.3650	0.2510	0.2118
5-12-P043-2	11	11	0.3634	0.3740	0.2160	0.2176
5-12-P046-3	16	16	0.3569	0.4060	0.2400	0.2759
5-12-P054-1	8	11	0.3696	0.4230	0.1690	0.1876

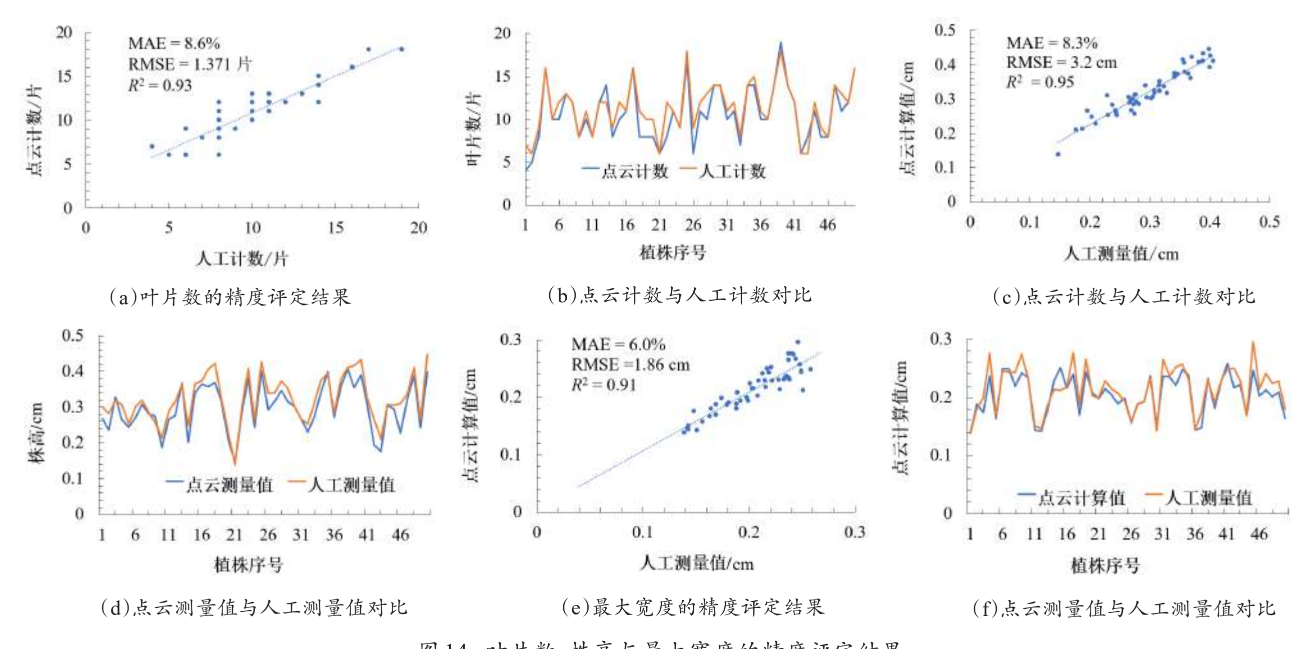
续表2

编号	叶片数/片		株高/m		最大宽度/m	
	算法测量值	人工计数值	算法测量值	人工测量值	算法测量值	人工测量值
5-12-P060-3	8	10	0.3160	0.3240	0.2440	0.2661
5-12-P065-2	8	10	0.2091	0.2290	0.2080	0.2026
5-12-P076-2	6	6	0.1467	0.1390	0.1980	0.1994
5-12-P099-1	8	12	0.2771	0.2920	0.2150	0.2289
5-12-P120-1	11	11	0.3817	0.4080	0.2040	0.2148
5-12-P124-3	9	9	0.2435	0.2630	0.1890	0.2076
5-12-P129-2	17	18	0.4009	0.4270	0.1990	0.1934
5-19-P279-3	6	9	0.2922	0.3390	0.1560	0.1575
5-19-P281-1	11	12	0.3149	0.3400	0.1880	0.1881
5-19-P281-2	10	13	0.3459	0.3730	0.1920	0.1934
5-19-P281-3	14	14	0.3156	0.3530	0.2370	0.2338
5-19-P294-3	14	14	0.3021	0.3020	0.1510	0.1423
5-19-P297-1	10	11	0.2689	0.2670	0.2370	0.2651
5-19-P002-2	11	12	0.2299	0.2530	0.2350	0.2366
5-19-P009-2	7	8	0.2744	0.3130	0.2210	0.2525
5-19-P015-2	14	14	0.3409	0.3750	0.2480	0.2571
5-19-P022-2	14	15	0.4000	0.3940	0.2380	0.2305
5-19-P028-3	10	11	0.2724	0.2840	0.1430	0.1436
5-19-P043-1	10	10	0.3582	0.3790	0.1480	0.1758
5-19-P043-2	14	14	0.4056	0.4110	0.2330	0.2305
5-19-P046-3	19	18	0.3546	0.4160	0.1810	0.1904
5-19-P054-1	14	14	0.3888	0.4330	0.2280	0.2298
5-19-P060-3	12	12	0.3070	0.3250	0.2580	0.2486
5-19-P065-2	6	6	0.1950	0.2660	0.2170	0.2502
5-19-P076-2	8	6	0.1761	0.2110	0.2220	0.2287
5-19-P099-1	11	12	0.3049	0.3080	0.1690	0.1691
5-19-P104-2	8	9	0.2943	0.3050	0.2460	0.2955
5-19-P104-2(2)	8	8	0.2282	0.3110	0.2030	0.2148
5-19-P104-3	14	14	0.3236	0.3370	0.2130	0.2411
5-19-P120-1	11	13	0.3883	0.4110	0.2010	0.2236
5-19-P124-3	12	12	0.2425	0.2670	0.2090	0.2281
5-19-P129-2	16	16	0.3985	0.4460	0.1640	0.1799

精度评估的结果如图14所示。叶片数、株高和最大宽度的MAPE分别为8.6%、8.3%和6.0%，RMSE分别为1.371片、3.2 cm和1.86 cm，R^2分别为0.93、0.95和0.91。这表明，本方法成功地提取了马铃薯的多源表型参数，且精度较高，显示出RGB图像和激光点云技术的优势得到了充分的发挥。综合MAPE、RMSE和R^2三个指标的评价结



果，可以充分验证本研究提出的方法在提取马铃薯表型参数方面的可行性和准确性。



(a)叶片数的精度评定结果 (b)点云计数与人工计数对比 (c)点云计数与人工计数对比

(d)点云测量值与人工测量值对比 (e)最大宽度的精度评定结果 (f)点云测量值与人工测量值对比

图14 叶片数、株高与最大宽度的精度评定结果

Fig. 14 Precision evaluation results of Leaf Number, Plant Height and Maximum Width

4 结论与展望

为了探索二维光学成像技术和三维激光扫描技术相互补充、相互协作、高效地提取表型参数的可行性，本研究使用RGB相机和激光扫描仪两种设备分别获取马铃薯的RGB顶视图像与点云数据，实现从二维RGB图像和三维激光点云数据中提取同一马铃薯的表型参数。

首先，在数据采集方面，采用华中农业大学作物表型平台的自动化传送装置，对马铃薯进行了高效的RGB图像采集，并通过实验确定了激光扫描仪的参数和站点设置，使得采集到的马铃薯点云数据完整且携带丰富的信息。

然后，采用了利用编号方法来建立植物表型参数与植株的对应关系，并在此基础上从RGB图像与激光点云两个方面提取马铃薯的共计18个表型参数，将马铃薯植株的RGB图像与点云数据结合起来，充分发挥了RGB图像与三维点云的优势，丰富了表型参数的类型。

最后，选择了比较具有代表性、易测量的叶片数、株高、最大宽度三个表型参数进行精度评估，MAPE分别为8.6%、8.3%和6.0%，RMSE分别为1.371片、3.2 cm和1.86 cm，决定系数R^2分别为0.93、0.95和0.91，证明了本研究所使用的方法的可行性和准确性。

同时，本研究也存在部分不足：提出的方法仅关注了马铃薯块茎形成阶段的植株冠层、茎秆和叶片的表型参数，缺乏对其他器官、块茎以及生长阶段的关注。为了解决这个问题，可以采集马铃薯不同时期的植株、花和块茎的RGB图像和点云数据，实现全生育期表型参数的动态变化展示和深度数据挖掘。同时，基于多源数据的表型参数提取可以推广到其他作物，如玉米、小麦、水稻等，并且采用更多设备，如热红外相机、叶绿素荧光仪、多光谱成像仪和高光谱成像仪，为作物表型参数的获取提供新的思路。

利益冲突声明：本研究不存在研究者以及与公开研究成果有关的利益冲突。

参考文献：

[1] 翁杨, 曾睿, 吴陈铭, 等. 基于深度学习的农业植物表型研究综述[J]. 中国科学(生命科学), 2019, 49(6): 698-716.
WENG Y, ZENG R, WU C M, et al. A survey on deep-learning-based plant phenotype research in agriculture[J]. Scientia sinica (vitae), 2019, 49(6): 698-716.

[2] GERMAIN C, ROUSSEAUD R, GRENIER G. Non destructive counting of wheatear with picture analysis[C]//

Fifth International Conference on Image Processing and its Applications. London, UK: IET, 2002: 435-439.
[3] 王传宇, 郭新宇, 杜建军, 等. 田间环境下玉米叶片图像分割方法及装置: CN106296662B[P]. 2019-07-02.
WANG C Y, GUO X Y, DU J J, et al. Corn leaf image segmentation method and apparatus in field environment: CN106296662B[P]. 2019-07-02.
[4] LORESCO P J M, VALENZUELA I C, DADIOS E P. Color space analysis using KNN for lettuce crop stages identification in smart farm setup[C]// TENCON 2018—2018 IEEE Region 10 Conference. Piscataway, NJ, USA: IEEE, 2019: 2040-2044.
[5] GRINBLAT G L, UZAL L C, LARESE M G, et al. Deep learning for plant identification using vein morphological patterns[J]. Computers and electronics in agriculture, 2016, 127: 418-424.
[6] LEE S H, CHAN C S, WILKIN P, et al. Deep-plant: Plant identification with convolutional neural networks[C]// 2015 IEEE International Conference on Image Processing (ICIP). Piscataway, NJ, USA: IEEE, 2015: 452-456.
[7] FAN Z Q, SUN N, QIU Q, et al. A high-throughput phenotyping robot for measuring stalk diameters of maize crops[C]// 2021 IEEE 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER). Piscataway, NJ, USA: IEEE, 2021: 128-133.
[8] 王晓婷, 赵展, 王阳, 等. 基于改进Mask R-CNN的植物表型智能检测算法[J]. 中国农机化学报, 2022, 43(8): 151-157.
WANG X T, ZHAO Z, WANG Y, et al. Intelligent detection algorithm of plant phenotype based on improved Mask R: CNN[J]. Journal of Chinese agricultural mechanization, 2022, 43(8): 151-157.
[9] ZHANG J Y, ZHAO X L, CHEN Z, et al. A review of deep learning-based semantic segmentation for point cloud[J]. IEEE access, 2019, 7: 179118-179133.
[10] 周静静, 郭新宇, 吴升, 等. 基于多视角图像的植物三维重建研究进展[J]. 中国农业科技导报, 2019, 21(2): 9-18.
ZHOU J J, GUO X Y, WU S, et al. Research progress on plant three-dimensional reconstruction based on multi-view images[J]. Journal of agricultural science and technology, 2019, 21(2): 9-18.
[11] WANG Y J, WEN W L, WU S, et al. Maize plant phenotyping: Comparing 3D laser scanning, multi-view stereo reconstruction, and 3D digitizing estimates[J]. Remote sensing, 2018, 11(1): ID 63.
[12] WANG Y W, CHEN Y F. Non-destructive measurement of three-dimensional plants based on point cloud[J]. Plants (basel, Switzerland), 2020, 9(5): 571.
[13] 阳旭, 胡松涛, 王应华, 等. 利用多时序激光点云数据提取棉花表型参数方法[J]. 智慧农业(中英文), 2021, 3(1): 51-62.
YANG X, HU S T, WANG Y H, et al. Cotton phenotypic trait extraction using multi-temporal laser point clouds[J]. Smart agriculture, 2021, 3(1): 51-62.
[14] 屈冬玉, 谢开云, 金黎平, 等. 中国马铃薯产业发展与食物安全[J]. 中国农业科学, 2005, 38(2): 358-362.
QU D Y, XIE K Y, JIN L P, et al. Development of potato industry and food security in China[J]. Scientia agricultura Sinica, 2005, 38(2): 358-362.
[15] 张兆国, 张振东, 李加念, 等. 采用改进YOLOv4模型检测复杂环境下马铃薯[J]. 农业工程学报, 2021, 37(22): 170-178.
ZHANG Z G, ZHANG Z D, LI J N, et al. Potato detection in complex environment based on improved YOLOv4 model[J]. Transactions of the Chinese society of agricultural engineering, 2021, 37(22): 170-178.
[16] 赵越, 赵辉, 姜永成, 等. 基于深度学习的马铃薯叶片病害检测方法[J]. 中国农机化学报, 2022, 43(10): 183-189.
ZHAO Y, ZHAO H, JIANG Y C, et al. Detection method of potato leaf diseases based on deep learning[J]. Journal of Chinese agricultural mechanization, 2022, 43(10): 183-189.
[17] 谭彧, 田芳, 刘星星, 等. 基于RGB-D相机的马铃薯图像采集装置及芽眼识别和定位方法: CN108830272A[P]. 2018-11-16.
TAN Y, TIAN F, LIU X X, et al. Potato image acquisition device based on RGB-D cameras and method for identifying and locating bud eye: CN108830272A[P]. 2018-11-16.
[18] 冯慧, 杨万能, 叶军立, 等. 一种用于盆栽水稻高光谱自动成像的双通道自动输送装置及控制方法: CN107720213B[P]. 2020-10-27.
FENG H, YANG W N, YE J L, et al. Automatic two-channel conveying device for automatic hyperspectral imaging of rice plants and control method: CN107720213B[P]. 2020-10-27.
[19] YUAN Y H, CHEN X K, CHEN X L, et al. Segmentation transformer: Object-contextual representations for semantic segmentation[J/OL]. arXiv: 1909.11065, 2019.
[20] 宋立鹏. 室外场景三维点云数据的分割与分类[D]. 大连: 大连理工大学, 2016.
SONG L P. Segmentation and classification of 3D point cloud data in outdoor scenes[D]. Dalian: Dalian University of Technology, 2016.
[21] RUSU R B. Semantic 3D object maps for everyday manipulation in human living environments[J]. KI-Künstliche Intelligenz, 2010, 24: 345-348.
[22] HARTIGAN J A, WONG M A. A K-means clustering algorithm[J]. Journal of the royal statistical society: Series C (applied statistics), 1979, 28(1): 100-108.
[23] 方敏, 徐俊艳, 王建平, 等. 一种新的文本图像二值化方法[J]. 合肥工业大学学报(自然科学版), 2001, 24(2): 166-169
FANG M, XU J Y, WANG J P, et al. A new binarization algorithm for document image[J]. Journal of Hefei university of technology (Natural Science), 2001, 24(2): 166-169
[24] LECUN Y, CORTES C, BURGES C J C. THE MNIST DATABASE of handwritten digits [EB/OL]. (1996-11-08) [2023-01-10]. http://yann.lecun.com/exdb/mnist
[25] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Commun ACM, 2017, 60(6): 84-90.

[26] 熊雄. 基于深度学习的大田水稻稻穗分割及无损产量预估研究[D]. 武汉: 华中科技大学, 2018.
XIONG X. Study on rice ear segmentation and lossless yield prediction of field rice based on deep learning[D]. Wuhan: Huazhong University of Science and Technology, 2018.
[27] 杨万里, 段凌凤, 杨万能. 基于深度学习的水稻表型特征提取和穗质量预测研究[J]. 华中农业大学学报, 2021, 40(1): 227-235.
YANG W L, DUAN L F, YANG W N. Deep learning-based extraction of rice phenotypic characteristics and prediction of rice panicle weight[J]. Journal of Huazhong agricultural university, 2021, 40(1): 227-235.
[28] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]// European conference on computer vision. Berlin, German: Springer, 2018: 833-851.
[29] XIAO T T, LIU Y C, ZHOU B L, et al. Unified perceptual parsing for scene understanding[C]// European Conference on Computer Vision. Berlin, German: Springer, 2018: 432-448.
[30] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 8759-8768.

Extraction of Potato Plant Phenotypic Parameters Based on Multi-Source Data

HU Songtao[1], ZHAI Ruifang[1*], WANG Yinghua[2], LIU Zhi[1], ZHU Jianzhong[1], REN He[1], YANG Wanneng[2,3], SONG Peng[2,3]

(1. *College of Informatics*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*;
2. *College of Plant Science & Technology*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*;
3. *National Key Laboratory of Crop Genetic Improvement*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*)

Abstract: Crops have diverse structures and complex growth environments. RGB image data can reflect the texture and color features of plants accurately, while 3D data contains information about crop volume. The combination of RGB image and 3D point cloud data can achieve the extraction of two-dimensional and three-dimensional phenotypic parameters of crops, which is of great significance for the research of phenomics methods. In this study, potatoe plants were chosen as the research subject, and RGB cameras and laser scanners were used to collect 50 potato RGB images and 3D laser point cloud data. The segmentation accuracy of four deep learning semantic segmentation methods, OCRNet, UpNet, PaNet, and DeepLab v3+, were compared and analyzed for the RGB images. OCRNet, which demonstrated higher accuracy, was used to perform semantic segmentation on top-view RGB images of potatoes. Mean shift clustering algorithm was optimized for laser point cloud data processing, and single-plant segmentation of laser point cloud data was completed. Stem and leaf segmentation of single-plant potato point cloud data were accurately performed using Euclidean clustering and K-Means clustering algorithms. In addition, a strategy was proposed to establish a one-to-one correspondence between RGB images and point clouds of single-plant potatoes using pot numbering. 8 2D phenotypic parameters and 10 3D phenotypic parameters, including maximum width, perimeter, area, plant height, volume, leaf length, and leaf width, etc., were extracted from RGB images and laser point clouds, respectively. Finally, the accuracy of three representative and easily measurable phenotypic parameters, leaf number, plant height, and maximum width were evaluated. The mean absolute percentage errors (MAPE) were 8.6%, 8.3% and 6.0%, respectively, while the root mean square errors (RMSE) were 1.371 pieces, 3.2 cm and 1.86 cm, respectively, and the determination coefficients (R^2) were 0.93, 0.95 and 0.91, respectively. The research results indicated that the extracted phenotype parameters can accurately and efficiently reflect the growth status of potatoes. Combining the RGB image data of potatoes with three-dimensional laser point cloud data can fully exploit the advantages of the rich texture and color characteristics of RGB images and the volumetric information provided by three-dimensional point clouds, achieving non-destructive, efficient, and high-precision extraction of two-dimensional and three-dimensional phenotype parameters of potato plants. The achievements of this study could not only provide important technical support for the cultivation and breeding of potatoes but also provide strong support for phenotype-based research.

Key words: LiDAR; multi-source data; Clustering segmentation; 3D phenotyping; OCRNet; LiDAR points cloud; deep learning